



ECARTOMÉTRIE DES RÉSEAUX PHASÉS ANTIBROUILLÉS

YVES GUÉZENGAR

Office National d'Etudes et de Recherches Aérospatiales
ONERA DES/STD BP 72 92322 Châtillon CEDEX

RÉSUMÉ

L'objet de cet article est d'estimer, avec un réseau phasé, la direction d'une source, supposée présente, quand on connaît la matrice de covariance des bruits reçus. Pour cela, on développe plusieurs modèles statistiques. Pour chacun d'entre eux, on construit un estimateur optimal, la borne inférieure de CRAMER-RAO (BCR) ainsi qu'une procédure pratique de localisation. En détaillant la signification physique des paramètres, on traite un grand nombre de problèmes radar : localisation avec des réseaux linéaires, plans, avec sous-réseaux ou avec compression d'impulsion. Une simulation permet de valider les résultats obtenus.

ABSTRACT

The aim of this paper is to estimate, with phased array, the direction of arrival of a Gaussian signal source, when the noise covariance matrix is known. Several stochastic signals model are developed. For each of them, we present the optimal estimator, the CRAMER-RAO bound and a practical estimation procedure. It is shown that these models deal with a lot of radar problems : localisation with 1-D and 2-D array, subarray and pulse compression waveforms. Simulation results ascertaining the performances of these methods are also presented.

Introduction

L'utilisation des procédures d'antibrouillage (CCM ou contre-contre mesures) avec les réseaux phasés est maintenant bien connue [1]. Ces procédures sont basées sur l'estimation de la matrice de covariance des bruits reçus. On supposera ici que cette matrice est connue. Deux problèmes se posent alors : la détection et l'estimation. Pour détecter, on peut, par exemple, tester le rapport signal à bruit plus interférences dans la direction, supposée connue, de la source. L'objet de cet article concerne le second problème : estimer la direction de la source, supposée présente.

La procédure d'écartométrie optimale après antibrouillage, développée en [2], est reprise ici en utilisant des modèles statistiques plus généraux. Pour chaque modèle développé, la théorie de l'estimation [3] permet de déterminer l'estimateur optimal des paramètres du modèle ainsi que la BCR. On met également en œuvre la méthode de NEWTON-RAPHSON [4] pour construire une procédure pratique de localisation.

L'article se compose de deux parties. La première concerne le développement théorique : présentation des modèles statistiques, de la BCR et de la mise en œuvre de la procédure optimale. La seconde partie expose les applications pratiques.

1 Modèles statistiques

Soient $\theta = (\theta_1, \dots, \theta_m)$ m réels quelconques, s et $(s^l)_{l \in [1, L]}$ $L + 1$ nombres complexes, $D(\theta)$ et $(D_l(\theta))_{l \in [1, L]}$ $L + 1$ fonctions de \mathbb{R}^m dans \mathbb{C}^n deux fois continûment dérivables. Soient X et $(X_l)_{l \in [1, L]}$ $L + 1$ vecteurs complexes aléatoires gaussiens, de dimension n , B et $(B_l)_{l \in [1, L]}$ $L + 1$ vecteurs complexes aléatoires gaussiens indépendants, de dimension n , de moyenne nulle et de matrice de covariance M . Les différents modèles sont définis comme suit :

$$- \text{Modèle 1 : } X_l = s D_l(\theta) + B_l \quad \forall l \in [1, L] \quad (1)$$

$$- \text{Modèle 2 : } X_l = s^l D(\theta) + B_l \quad \forall l \in [1, L] \quad (2)$$

$$- \text{Modèle 3 : } X_l = s D(\theta) + B_l \quad \forall l \in [1, L] \quad (3)$$

$$- \text{Modèle 4 : } X = s D(\theta) + B \quad (4)$$

Pour garder la généralité des modèles proposés, la signification physique des paramètres n'est détaillée qu'en seconde partie. Les modèles 1, 3 et 4 dépendent de $m + 2$ paramètres et le modèle 2 de $m + 2L$ paramètres. Les modèles 3 et 4 sont des cas particuliers du modèle 1. Il suffit de poser respectivement : $D_l(\theta) = D(\theta) \forall l \in [1, L]$ et $L = 1$.



L'estimateur optimal, au sens du maximum de vraisemblance, des $m + 2$ paramètres θ et s du modèle 1 est donné en maximisant sur \mathbb{R}^{m+2} la densité de probabilité $\Pr(X_1, \dots, X_L | s, \theta)$. En réduisant la partie linéaire de la maximisation, on obtient :

$$\hat{\theta} = \underset{\theta \in \mathbb{R}^m}{\operatorname{argmax}} \frac{\left| \sum_{l=1}^L D_l^h(\theta) M^{-1} X_l \right|^2}{\sum_{l=1}^L D_l^h(\theta) M^{-1} D_l(\theta)} \quad (5)$$

$$\hat{s} = \frac{\sum_{l=1}^L D_l^h(\hat{\theta}) M^{-1} X_l}{\sum_{l=1}^L D_l^h(\hat{\theta}) M^{-1} D_l(\hat{\theta})} \quad (6)$$

$D_l^h(\theta)$ est le transposé conjugué de $D_l(\theta)$. De la même façon, les $m + 2L$ paramètres θ et s^l du modèle 2 sont donnés par :

$$\hat{\theta} = \underset{\theta \in \mathbb{R}^m}{\operatorname{argmax}} \frac{\sum_{l=1}^L |D^h(\theta) M^{-1} X_l|^2}{D^h(\theta) M^{-1} D(\theta)} \quad (7)$$

$$\hat{s}^l = \frac{D^h(\hat{\theta}) M^{-1} X_l}{D^h(\hat{\theta}) M^{-1} D(\hat{\theta})} \quad (8)$$

La borne de Cramer-Rao est donnée par l'inverse de la matrice d'information de Fisher J [3]. En effectuant une inversion partielle, on réduit la dimension à m . On obtient pour le modèle 1 :

$$\operatorname{var}(\hat{\theta}_i) \geq \frac{\left(\tilde{J}^{-1}(\hat{\theta}) \right)_{i,i}}{2 |s|^2 \sum_{l=1}^L D_l^h(\hat{\theta}) M^{-1} D_l(\hat{\theta})} \quad \forall i \in [1, m] \quad (9)$$

$$\operatorname{avec} \quad \left(\tilde{J}(\theta) \right)_{i,j} = \Re e \left(\frac{\sum_{l=1}^L \nabla_{\theta_i} D_l^h(\theta) M^{-1} \nabla_{\theta_j} D_l(\theta)}{\sum_{l=1}^L D_l^h(\theta) M^{-1} D_l(\theta)} \right. \\ \left. - \frac{\sum_{l=1}^L \nabla_{\theta_i} D_l^h(\theta) M^{-1} D_l(\theta) \times \sum_{l=1}^L D_l^h(\theta) M^{-1} \nabla_{\theta_j} D_l(\theta)}{\left(\sum_{l=1}^L D_l^h(\theta) M^{-1} D_l(\theta) \right)^2} \right) \quad (10)$$

On note $\nabla_{\theta_i} D_l(\theta)$ le vecteur $\frac{\partial D_l(\theta)}{\partial \theta_i}$. Pour le modèle 2, on obtient :

$$\operatorname{var}(\hat{\theta}_i) \geq \frac{\left(\tilde{J}^{-1}(\hat{\theta}) \right)_{i,i}}{2 \sum_{l=1}^L |s^l|^2 D^h(\hat{\theta}) M^{-1} D(\hat{\theta})} \quad \forall i \in [1, m] \quad (11)$$

$$\operatorname{avec} \quad \left(\tilde{J}(\theta) \right)_{i,j} = \Re e \left(\frac{\nabla_{\theta_i} D^h(\theta) M^{-1} \nabla_{\theta_j} D(\theta)}{D^h(\theta) M^{-1} D(\theta)} \right. \\ \left. - \frac{\nabla_{\theta_i} D^h(\theta) M^{-1} D(\theta) D^h(\theta) M^{-1} \nabla_{\theta_j} D(\theta)}{\left(D^h(\theta) M^{-1} D(\theta) \right)^2} \right) \quad (12)$$

La mise en œuvre de l'estimateur optimal s'effectue à l'aide de la méthode itérative de Newton-Raphson [4]. En remplaçant dans le Hessien les vecteurs X_l par leurs espérances, on obtient une formulation qui fait apparaître la matrice $\tilde{J}(\theta)$:

$$\hat{\theta}^{(k+1)} = \hat{\theta}^{(k)} - \left(\tilde{J}(\hat{\theta}^{(k)}) \right)^{-1} V(\hat{\theta}^{(k)}) \quad (13)$$

avec, pour le modèle 1, $\tilde{J}(\theta)$ donnée par (10) et

$$(V(\theta))_i = \Re e \left(\frac{\sum_{l=1}^L \nabla_{\theta_i} D_l^h(\theta) M^{-1} D_l(\theta)}{\sum_{l=1}^L D_l^h(\theta) M^{-1} D_l(\theta)} \right. \\ \left. - \frac{\sum_{l=1}^L \nabla_{\theta_i} D_l^h(\theta) M^{-1} X_l}{\sum_{l=1}^L D_l^h(\theta) M^{-1} X_l} \right) \quad (14)$$

et pour le modèle 2, $\tilde{J}(\theta)$ donnée par (12) et

$$(V(\theta))_i = \Re e \left(\frac{\nabla_{\theta_i} D^h(\theta) M^{-1} D(\theta)}{D^h(\theta) M^{-1} D(\theta)} \right. \\ \left. - \frac{\sum_{l=1}^L \nabla_{\theta_i} D^h(\theta) M^{-1} X_l X_l^h M^{-1} D(\theta)}{\sum_{l=1}^L |D^h(\theta) M^{-1} X_l|^2} \right) \quad (15)$$

2 Applications

En détaillant la signification physique des paramètres des modèles, on traite une grande partie des problèmes d'écartométrie rencontrés en radar : (i) écartométrie avec un réseau linéaire sans compression d'impulsion. On montre le lien existant avec la procédure classique du type monopulse. On développe également une expression simplifiée de la BCR pour le cas d'un brouilleur unique (ii) écartométrie avec un réseau plan. On montre que l'écartométrie ne peut pas se mettre sous la forme d'un double monopulse (résultat déjà constaté par Nickel [5]) (iii) écartométrie avec compression d'impulsion. On discute l'influence de la position du filtre adapté (avant ou après CCM) sur l'écartométrie.

Le réseau linéaire est défini par n abscisses $(x_i)_{i \in [1, n]}$. On se place dans une configuration sans compression d'impulsion où un seul échantillon du signal est traité ($L=1$). On utilise donc le modèle 4 : $X = sD(u) + B$ où X est le vecteur des signaux reçus sur chaque capteur, s l'amplitude complexe de la source, $D(u)$ le vecteur de focalisation de terme général : $(D(u))_i = e^{j \frac{2\pi}{\lambda} u x_i}$ avec u cosinus directeur de la direction de la source et λ la longueur d'onde. La procédure d'écartométrie issue de (13), s'écrit : $\hat{u}^{(k+1)} = \hat{u}^{(k)} - \delta \hat{u}^{(k)}$ avec :

$$\delta u = \frac{\Re e \left(\frac{\nabla_u D^h M^{-1} D}{D^h M^{-1} D} \right) - \Re e \left(\frac{\nabla_u D^h M^{-1} X}{D^h M^{-1} X} \right)}{\frac{\nabla_u D^h M^{-1} \nabla_u D}{D^h M^{-1} D} - \frac{|\nabla_u D^h M^{-1} D|^2}{\left(D^h M^{-1} D \right)^2}} \quad (16)$$

et $(\nabla_u D)_i = j \frac{2\pi}{\lambda} x_i e^{j \frac{2\pi}{\lambda} u x_i}$.

Pour faire le lien avec la procédure monopulse adaptée aux réseaux phasés avec CCM, on écrit les signaux reçus sous la forme : $y_2 = D^h(u_v \mp \frac{\epsilon}{2}) M^{-1} X$ avec u_v cosinus directeur de la direction de visée et ϵ l'écart entre les deux voies. En posant $X = D(u_v - \delta u)$ dans le rapport $\frac{\Delta}{S} = (y_1 - y_2) / (y_1 + y_2)$ et en faisant tendre ϵ vers 0, on obtient, après linéarisation, une expression $\delta u = \alpha \left(\frac{\Delta}{S} - \beta \right)$ identique à (16). On constate ainsi



que l'écartométrie monopulse équivaut à une itération dans la recherche de l'estimateur optimal du maximum de vraisemblance : c'est donc un estimateur sous-optimal. On note également que l'antibrouillage a deux conséquences sur le monopulse standard : il introduit un biais β et il rend α et β dépendants de la direction de visée et des caractéristiques du bruit (matrice M).

Pour obtenir une expression plus explicite de la BCR, on développe (9) pour le cas d'un brouilleur unique en écrivant $M = \sigma^2 I + P_b J J^h$ avec σ^2 puissance du bruit thermique, P_b puissance du brouilleur et J vecteur direction défini à l'aide du cosinus directeur u_b : $(J)_i = e^{j2\pi u_b x_i}$. On montre que la BCR s'écrit en fonction des 5 grandeurs suivantes : 1) $(S/B)_s = n |s|^2 / \sigma^2$ rapport signal à bruit thermique en sortie de réseau en l'absence de brouillage, 2) $(J/B)_s = n P_b / \sigma^2$ rapport brouilleur à bruit thermique en sortie, 3) $|g_{u_b}|^2 = |D^h|^2 / n^2$ gain en puissance du brouilleur lorsqu'on vise la source, 4) $|g'_{u_b}|^2 = |\nabla_u D^h|^2 / n^2$ module carré de la dérivée du gain complexe dans la direction du brouilleur et 5) $\text{var}(\frac{2\pi}{\lambda} x) = \frac{1}{n} \nabla_u D^h \nabla_u D = \frac{1}{n} \sum_{i=1}^n (\frac{2\pi}{\lambda} x_i)^2$ étendue spatiale du réseau. On suppose aussi que le réseau est centré ($\sum_{i=1}^n x_i = 0$). Cette condition ne modifie que la forme de l'expression de la BCR qui reste invariante pour toute translation de l'axe des x . On obtient :

$$\text{var}(\hat{u}) \geq \frac{1}{2(S/B)_s} \left(\text{var}(\frac{2\pi}{\lambda} x) - \frac{|g'_{u_b}|^2}{\frac{1}{(J/B)_s} + 1 - |g_{u_b}|^2} \right)^{-1}$$

On constate que la présence du brouilleur augmente la borne et que plus le réseau est étendu meilleure est la localisation. On constate également que l'approximation brouilleur fort s'écrit : $(J/B)_s \gg 1 / (1 - |g_{u_b}|^2)$; pour un écart source-brouilleur supérieur à une valeur fixée, il existe un $(J/B)_s$ seuil à partir duquel la BCR reste constante. En l'absence de brouilleur, on retrouve la formule de Woodward [6] : $\sigma(\hat{u}) \geq (2\pi\sigma / \lambda) \sqrt{2(S/B)_s}^{-1}$.

Le réseau plan est défini en numérotant de façon quelconque les n capteurs de coordonnées $(x_i, y_i)_{i \in [1, n]}$. On utilise le modèle 4 avec $m = 2$: $X = sD(u, v) + B$ où $(X)_i$ est le signal reçu sur le capteur i et $(D(u, v))_i = e^{j2\pi(u x_i + v y_i)}$ avec (u, v) cosinus directeur de la source. La procédure d'écartométrie optimale s'écrit sous forme matricielle :

$$\begin{pmatrix} \hat{u}^{(k+1)} \\ \hat{v}^{(k+1)} \end{pmatrix} = \begin{pmatrix} \hat{u}^{(k)} \\ \hat{v}^{(k)} \end{pmatrix} - \begin{pmatrix} \tilde{J}_1 & \tilde{J}_2 \\ \tilde{J}_2 & \tilde{J}_3 \end{pmatrix}^{-1} \begin{pmatrix} V_1 \\ V_2 \end{pmatrix} \quad (17)$$

$$\text{avec } V_2 = \Re e \left(\frac{\nabla_u D^h M^{-1} D}{D^h M^{-1} D} - \frac{\nabla_u D^h M^{-1} X}{D^h M^{-1} X} \right) \quad (18)$$

$$\text{et } \tilde{J}_3 = \frac{\nabla_u D^h M^{-1} \nabla_u D}{D^h M^{-1} D} - \frac{|\nabla_u D^h M^{-1} D|^2}{(D^h M^{-1} D)^2} \quad (19)$$

$$\tilde{J}_2 = \Re e \left(\frac{\nabla_u D^h M^{-1} \nabla_u D}{D^h M^{-1} D} - \frac{\nabla_u D^h M^{-1} D D^h M^{-1} \nabla_u D}{(D^h M^{-1} D)^2} \right) \quad (20)$$

L'équation (17) ne peut pas se mettre sous la forme d'un double monopulse en u et v (équation (16)) car \tilde{J}_2 est non nul. On montre ainsi que les localisations en u et v sont liées. \tilde{J}_2 ne s'annule qu'en l'absence de brouilleur ($M = \sigma^2 I$) et pour un réseau à covariance nulle. Dans ce cas, on a :

$$\tilde{J}_2 / \left(\frac{2\pi}{\lambda}\right)^2 = \frac{1}{n} \sum_{i=1}^n x_i y_i - \frac{1}{n^2} \sum_{i=1}^n x_i \times \sum_{i=1}^n y_i = \text{cov}(x, y) = 0$$

Compression d'impulsion. La source est présente sur plusieurs instants d'échantillonnage. Deux méthodes sont utilisées.




Figure 1.A

La première méthode *filtre adapté en tête* (figures 1) décode temporellement les signaux reçus puis détermine la direction de la source. On montre que cette méthode est issue du modèle 1 qui considère les signaux reçus cohérents d'un instant d'échantillonnage à l'autre.




Figure 1.B

La seconde méthode *filtre adapté en fin* (figure 2) qui détermine d'abord la direction d'arrivée puis décode les amplitudes estimées des signaux reçus, n'utilise aucune hypothèse de cohérence des signaux (modèle 2).

► **FILTRE ADAPTÉ EN TÊTE.**

Soient δt la période d'échantillonnage dans la récurrence, L le nombre d'échantillons et $a_l \in [1, L]$ la valeur du code source à l'instant $(l-1)\delta t$. En supposant que pendant la durée $L\delta t$ les brouilleurs sont stationnaires, on peut utiliser le modèle 1 : $X_l = sD_l(u, v) + B_l \quad \forall l \in [1, L]$ avec X_l le vecteur des signaux reçus à l'instant $l\delta t$ et $(D_l(u, v))_i = a_l e^{j2\pi(u x_i + v y_i)}$

On montre qu'il est possible de se ramener à une configuration sans compression d'impulsion, en reportant l'expression de $D_l(u, v)$ dans les équations (5) et (6). On obtient :

$$(\hat{u}, \hat{v}) = \underset{(u, v) \in \mathbb{R}^2}{\text{argmax}} \frac{|D^h M^{-1} \bar{X}|^2}{D^h M^{-1} D} \quad \hat{s} = \frac{D(a, \theta) M^{-1} \bar{X}}{\sqrt{\sum_{i=1}^L |a_i|^2}} \quad (21)$$

avec $(D(u, v))_i = e^{j2\pi(u x_i + v y_i)}$ et :

$$\bar{X} = \left(\sum_{i=1}^L a_i^* X_i \right) / \sqrt{\sum_{i=1}^L |a_i|^2} \quad (22)$$




Figure 2



a_l^* étant le conjugué de a_l . On retrouve dans l'expression de X_l une structure où les filtres adaptés sont implantés après chaque capteur (figure 1.A). La procédure d'écartométrie optimale est donnée par (17) avec \tilde{J} donnée par (19) et (20) et V donné en remplaçant X par \bar{X} dans (18). Si on écrit V sous la forme :

$$V_2 = \Re e \left(\frac{\nabla_u D^h M^{-1} D}{D^h M^{-1} D} - \frac{\sum_{l=1}^L a_l^* \nabla_u D^h M^{-1} X_l}{\sum_{l=1}^L a_l^* D^h M^{-1} X_l} \right) \quad (23)$$

on obtient une structure équivalente avec les filtres adaptés après formation de voies (figure 1.B). Bien que le nombre de filtre adapté soit différent, la charge de calcul est du même ordre de grandeur pour les deux structures. En effet, pour la structure B, il faut recalculer la sorties des filtres à chaque itération (17). La structure B devient avantageuse pour une configuration de veille (sans localisation) et quand le nombre de directions à scruter est inférieur au nombre de capteurs.

► **FILTRE ADAPTÉ EN FIN.** On estime l'amplitude des L vecteurs X_l sachant qu'ils proviennent tous de la direction $D(u, v)$. On utilise donc le modèle 2 : $X_l = s^l D(\theta) + B_l$. L'estimation de (u, v) est donnée par (17) avec \tilde{J} et V tirés de (12) et (15). Une fois la direction de la source estimée, les \hat{s}^l sont données par (8). La sortie du filtre adapté est déterminée à partir des \hat{s}^l par :

$$\hat{s} = \left(\sum_{l=1}^L a_l^* \hat{s}^l \right) / \sqrt{\sum_{l=1}^L |a_l|^2} \quad (24)$$

► **COMPARAISON ENTRE LES DEUX MODÈLES.** Pour le modèle 1 l'estimation de la puissance totale des L échantillons est donnée par : $\hat{P}_c = |\hat{s}|^2 \sum_{l=1}^L |a_l|^2$ et pour le modèle 2 par : $\hat{P}_c = |\hat{s}|^2$. On montre que pour les deux modèles, on obtient une expression identique :

$$\hat{P}_c = |D^h M^{-1} \bar{X}|^2 / (D^h M^{-1} D)^2 \quad (25)$$

Seul le point d'évaluation diffère entre les deux modèles. Ainsi, le résultat est identique pour une direction de visée fixée (sans localisation) mais avec moins d'opérations pour le modèle 2. Avec localisation, on constate que, pour le modèle 2, le gain de calcul apporté en supprimant $n - 1$ filtres adaptés, est annulé par une localisation plus coûteuse. En comparant l'expression de la BCR pour les deux modèles, on constate également qu'on obtient la même précision de mesure en localisation, quand on utilise le modèle 2 avec des signaux qui sont modélisables avec le modèle 1 (en posant $s^l = sa_l$).

Sous-réseau. Soit un réseau constitué de n sous-réseaux de direction de visée (u_v, v_v) proche de la direction source (u, v) . Soit $g_i(u, v)$ le diagramme de gain du $i^{\text{ème}}$ sous-réseau. Pour utiliser les différentes procédures de localisation développées précédemment, il suffit de poser :

$(D(u, v))_i = g_i(u, v) e^{j \frac{2\pi}{\lambda} (ux_i + vy_i)}$. Le gradient s'écrit alors :

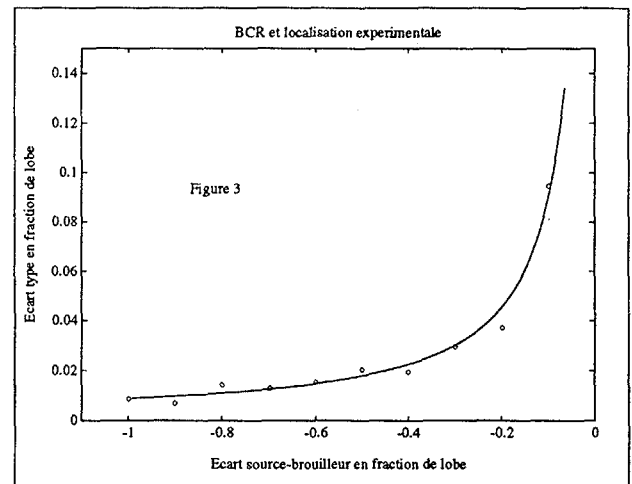
$$(\nabla_u D(u, v))_i = \left(\frac{\partial g_i}{\partial u}(u, v) + j \frac{2\pi}{\lambda} x_i \right) e^{j \frac{2\pi}{\lambda} (ux_i + vy_i)} \quad (26)$$

Conclusion

On a montré qu'à partir de quelques modèles statistiques simples, on peut traiter un grand nombre de problèmes radar. Outre la localisation avec des réseaux linéaires, plans, avec sous-réseaux ou avec compression d'impulsion, on peut également traiter les problèmes de localisation distance et doppler et d'intégration cohérente (modèle 3).

Pour valider les résultats obtenus, on effectue une simulation avec un réseau linéaire de 28 capteurs (largeur du lobe $u_0 = 2/28 \approx 4^\circ$) équidistants de $\lambda/2$ et $|s|^2 = 1$ $P_b = 100$ $\sigma^2 = 0,01$. On présente figure 3 la BCR (trait plein) en fonction de l'écart source/brouilleur en fraction de lobe $((u - u_b)/u_0)$. On détermine également l'écart type expérimental (sur 20 simulations) obtenu à l'aide de la procédure d'écartométrie (16) itérée 2 fois. La valeur initiale $u^{(0)}$ est équirépartie sur $[-u_0/2, u_0/2]$.

On constate que la précision de mesure suit bien la BCR.



- [1] J.E. HUDSON, "Adaptive array principles", IEE series, Peter Peregrinus, U.K. 1981.
- [2] R.C. DAVIES, L.E. BRENNAN, I.S. REED, "Angle estimation with adaptive arrays in external noise fields", IEEE Trans. AES-12, p 179-186, 1976.
- [3] H.L. VAN TREES, "Detection, estimation and modulation theory", PART I, New-York, Wiley, 1971.
- [4] E. POLAK, "Computational methods in optimisation", Academic Press, 1971.
- [5] U. NICKEL, "A corrected monopulse estimation methods for adaptive arrays", Congrès Radar, Brighton, 1992
- [6] A.W. RIHACZEK, "Principles of high-resolution radar", New-York, Mc Graw-Hill, 1969